DOCUMENT PROCESSOR AND STORAGE MEDIUM

Publication number: JP11259498

Publication date:

1999-09-24

Inventor:

HASHIMOTO MINAKO; KASHINO WAKAKO;

OCHITANI AKIRA; NISHINO FUMITO

Applicant:

FUJITSU LTD

Classification:

- international:

G06F17/21; G06F17/30; G06F17/21; G06F17/30;

(IPC1-7): G06F17/30; G06F17/21

- European:

G06F17/30T1E

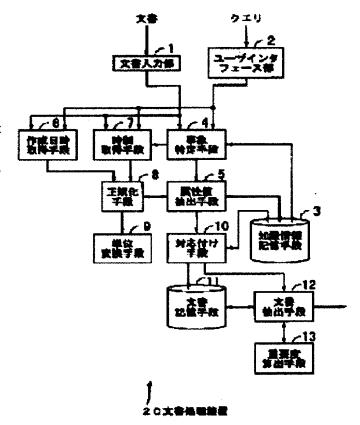
Application number: JP19980058384 19980310 Priority number(s): JP19980058384 19980310 Also published as:

WO9946698 (A1)
US6523025 (B1)
GB2350712 (A)
CN1286776 (A)
CN1109994C (C)

Report a data error here

Abstract of JP11259498

PROBLEM TO BE SOLVED: To enhance retrieving or clipping accuracy of a document. SOLUTION: The document to be processed is inputted from a document input part 1. A type of an event described on the inputted document is specified by referring to knowledge information stored in a knowledge information storage means 3 by an event specifying means 4. An attribute value of an attribute regarding the specified event is extracted from the document by an attribute value extracting means 5. A processing to make the attribute value extracted by the attribute value extracting means 5 correspond to substance in the real world is performed by a corresponding means 10. Information (normalized information) generated by the corresponding means 10 and information to specify the document or a place in which the document is stored are stored by correlating them by a document storage means 11. A query inputted from a user interface part 2 is compared with the normalized information and the information to specify the applicable document or the place in which the document is stored is outputted from the document storage means 11 by a document extracting means 12.



Data supplied from the esp@cenet database - Worldwide

(19)日本国特許庁 (JP) (12) 公開特許公報 (A)

(11)特許出願公開番号

特開平11-259498

(43)公開日 平成11年(1999)9月24日

(51) Int.Cl. ⁶		識別記号	FΙ		
G06F	17/30		G06F	15/40	370A
	17/21			15/20	590E
				15/403	3 1 0 A
					350C
			審査請	求未請求	請求項の数10 OL

(21)出願番号

特顯平10-58384

(22)出願日

平成10年(1998) 3月10日

(71)出顧人 000005223

富士通株式会社

神奈川県川崎市中原区上小田中4丁目1番

1号

(72) 発明者 橋本 三奈子

神奈川県川崎市中原区上小田中4丁目1番

1号 富士通株式会社内

(72) 発明者 柏野 和佳子

神奈川県川崎市中原区上小田中4丁目1番

1号 富士通株式会社内

(74)代理人 弁理士 服部 毅巖

最終頁に続く

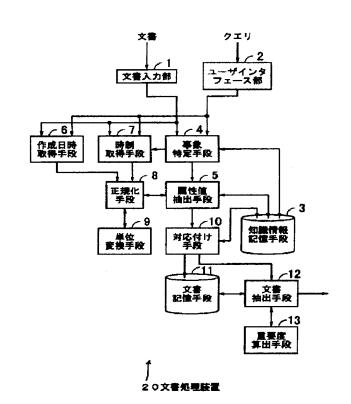
(全 20 頁)

(54) 【発明の名称】 文書処理装置および記録媒体

(57)【要約】

【課題】 文書の検索またはクリッピング精度を向上さ せる。

【解決手段】 文書入力部1からは処理の対象となる文 書が入力される。事象特定手段4は、知識情報記憶手段 3に記憶されている知識情報を参照して、入力された文 書に記述されている事象の種類を特定する。属性値抽出 手段5は、特定された事象に係わる属性の属性値を文書 から抽出する。対応付け手段10は、属性値抽出手段5 によって抽出された属性値を、実世界の実体に対して対 応付ける処理を行う。文書記憶手段11は、対応付け手 段10によって生成された情報(正規化情報)と、文書 または文書の格納場所を特定する情報とを関連付けて記 **憶する。文書抽出手段12は、ユーザインタフェース部** 2から入力されたクエリと、正規化情報とを比較し、該 当する文書または文書の格納場所を特定する情報を文書 記憶手段11から出力する。



【特許請求の範囲】

【請求項1】 入力された文書に対して所定の処理を施 して記憶するとともに、与えられたクエリに対応する文 書を、記憶されている文書の中から検索またはクリッピ ングする処理を行う文書処理装置において、

1

前記入力された文書を処理するために必要な知識情報を 記憶する知識情報記憶手段と、

前記入力された文書に記述されている事象の種類を、前 記知識情報記憶手段に記憶されている知識情報を参照し て特定する事象特定手段と、

前記事象特定手段によって特定された事象に係わる属性 の属性値を、前記知識情報記憶手段に記憶されている知 識情報を参照して前記文書から抽出する属性値抽出手段 と、

前記知識情報記憶手段に記憶された知識情報を参照し て、前記属性値抽出手段によって抽出された属性値と、 実世界の実体との対応付けを行う対応付け手段と、 前記対応付け手段によって対応付けがなされた属性値 と、前記文書または前記文書の格納場所を特定するため

前記属性値と前記クエリとを参照して、対象となる文書 に対して検索処理またはクリッピング処理を行う文書抽 出手段と、

の情報とを関連付けて記憶する文書記憶手段と、

を有することを特徴とする文書処理装置。

【請求項2】 前記対応付け手段は、前記属性値の中で 固有名であるものに対しては、他の属性値を参照してそ の固有名が示す実世界の実体を特定するとともに、特定 された実体を一意に示す所定の情報を付与し、

前記文書抽出手段は、前記対応付け手段によって付与さ れた前記所定の情報を参照して、検索処理またはクリッ 30 ピング処理を行うことを特徴とする請求項1記載の文書 処理装置。

【請求項3】 前記対応付け手段は、前記属性値が参照 表現である「同」または「両」を含む場合に、それらの 参照表現が参照する属性値を特定することを特徴とする 請求項1記載の文書処理装置。

【請求項4】 前記文書に含まれているキーワードの出 現頻度を参照して対象とする文書の重要度を算出する重 要度算出手段を更に有し、

前記重要度算出手段は、前記対応付け手段によって参照 40 先が特定された参照表現もキーワードと同等に処理する ことを特徴とする請求項3記載の文書処理装置。

【請求項5】 前記属性値のうち、数値化可能なものに 関しては、対応する数値に変換して正規化する正規化手 段を更に有し、

前記文書抽出手段は、前記正規化手段によって正規化さ れた情報を参照して、検索処理またはクリッピング処理 を行うことを特徴とする請求項1記載の文書処理装置。

【請求項6】 前記正規化手段によって得られた数値が 有する単位を、他の所定の単位に変換する単位変換手段 50

を更に有することを特徴とする請求項5記載の文書処理 装置。

【請求項7】 前記文書を構成する所定の文章の時制を 取得する時制取得手段と、

前記文書が作成された日時を取得する作成日時取得手段 とを更に有し、前記正規化手段は、前記時制取得手段に よって取得された文書の時制と、前記作成日時取得手段 によって取得された作成日時とを参照して、日時または 期間を示す属性値の具体的な値を推定することを特徴と する請求項5記載の文書処理装置。

【請求項8】 前記文書に含まれているキーワードの出 現頻度を参照して対象とする文書の重要度を算出する重 要度算出手段を更に有し、

前記重要度算出手段は、前記正規化手段によって推定さ れた日時または期間を加味して重要度を算出することを 特徴とする請求項7記載の文書処理装置。

【請求項9】 前記事象特定手段、前記属性抽出手段、 および、対応付け手段は、前記クエリに対しても文書の 場合と同様の処理を行い、

20 前記文書抽出手段は、前記対応付け手段によって対応付 けがなされた文書の属性値とクエリの属性値とを参照し て、検索またはクリッピング処理を行うことを特徴とす る請求項1記載の文書処理装置。

【請求項10】入力された文書に対して所定の処理を施 して記憶するとともに、与えられたクエリに対応する文 書を、記憶されている文書の中から検索またはクリッピ ングする処理をコンピュータに実行させるプログラムを 記録したコンピュータ読み取り可能な記録媒体におい て、

コンピュータを、

前記入力された文書を処理するために必要な知識情報を 記憶する知識情報記憶手段、

前記入力された文書に記述されている事象の種類を、前 記知識情報記憶手段に記憶されている知識情報を参照し て特定する事象特定手段、

前記事象特定手段によって特定された事象に係わる属性 の属性値を、前記知識情報記憶手段に記憶されている知 識情報を参照して前記文書から抽出する属性値抽出手 段、

前記知識情報記憶手段に記憶されている知識情報を参照 して、前記属性値抽出手段によって抽出された属性値 と、実世界の実体との対応付けを行う対応付け手段、 前記対応付け手段によって対応付けがなされた属性値 と、前記文書または前記文書の格納場所を特定するため の情報とを関連付けて記憶する文書記憶手段、

前記属性値と前記クエリとを参照して、対象となる文書 に対して検索処理またはクリッピング処理を行う文書抽 出手段、

として機能させるプログラムを記録したコンピュータ読 で 可能な記録媒体。

【発明の詳細な説明】

[0001]

【発明の属する技術分野】本発明は入力された文書に対して所定の処理を施して記憶するとともに、与えられたクエリに対応する文書を、記憶されている文書の中から検索またはクリッピングする処理を行う文書処理装置およびそのような処理をコンピュータに実行させるプログラムを記録した記録媒体に関する。

[0002]

【従来の技術】近年、インターネットの普及や全文デー 10 タベースの増加に伴って、個人が利用可能な情報が飛躍 的に増加している。

【0003】このような多量の情報の中から所望の情報を取得する方法としては、例えば、得ようとするデータの特徴を記述した検索式 (クエリ)をキーとして、検索処理やクリッピング処理等を行う方法が一般的であった。

[0004]

【発明が解決しようとする課題】しかし、従来の大規模な商用オンラインデータベースや全文検索システムでは、検索式の条件を緩やかにすると検索結果に含まれているノイズ(不要なデータ)が増加し、また、逆に厳しくすると検索洩れが発生するなど、ユーザが望む通りのデータを取得することが困難であるという問題があった。

【0005】即ち、従来の文書フィルタリングにおける 文書絞り込み処理や文書検索処理では、クエリと文書の 内容の一致度や関連度に基づくランキング検索が行われ ている程度であるので、文書に含まれている重要情報や ユーザの検索意図を十分に反映した文書絞り込みを行う ことは困難であった。

【0006】そのため、例えば、組織としての「橋本」が検索したいと思っても、「橋本」という地名が含まれた文書が検索されたりすることが多かった。また、20万円台の新製品について検索したい場合には、「二十万円」「20万円」、「二十万円」、「二五万円」のように、あらゆる可能性を考慮して生成したクエリを用いる必要があった。

【0007】更に、文書が作成された日時を用いて検索 することは可能であっても、文書に含まれている日時情 40 報を活用した検索を行うことができないという問題点が あった。

【0008】例えば、以下の文では、同じ「1日」でも示している日が異なる。

- (a) A社は、1日、B製品を発売する。
- (b) A社は、1日、B製品を発売した。

【0009】ここで、この文が作成された日が1997年2月15日だとすると、(a)の場合では、「1日」は1997年3月1日を指し、また、(b)では1997年2月1日を指すことになる。

【0010】従来の方法においては、文書中の日時情報の属性を認知した上で、このような情報を検索に使用 (活用) することが困難であるという問題点があった。本発明はこのような点に鑑みてなされたものであり、ユーザの検索意図を十分に反映した文書検索または文書絞り込みを行うことが可能な文書処理装置を提供することを目的とする。

【0011】また、本発明は、ユーザの検索意図を十分に反映した文書検索処理またはクリッピング処理を行う文書処理を行うプログラムを記録した記録媒体を提供することを目的とする。

[0012]

【課題を解決するための手段】図1は、上記目的を達成する本発明の原理図である。本発明は、入力された文書に対して所定の処理を施して記憶するとともに、与えられたクエリに対応する文書を、記憶されている文書の中から検索またはクリッピングする処理を行う文書処理装置において、知識情報記憶手段3と、事象特定手段4と、属性値抽出手段5と、対応付け手段10と、文書記憶手段11と、文書抽出手段12とから構成されている。

【0013】ここで、知識情報記憶手段3は、入力され た文書を処理するために必要な知識情報を記憶する。事 象特定手段4は、入力された文書に記述されている事象 の種類を、知識情報記憶手段3に記憶されている知識情 報を参照して特定する。属性値抽出手段5は、事象特定 手段4によって特定された事象に係わる属性の属性値 を、知識情報記憶手段3に記憶されている知識情報を参 照して文書から抽出する。対応付け手段10は、知識情 報記憶手段3に記憶されている知識情報を参照して、属 性値抽出手段5によって抽出された属性値と、実世界の 実体との対応付けを行う。文書記憶手段11は、対応付 け手段10によって対応付けがなされた属性値と、文書 または文書の格納場所を特定するための情報とを関連付 けて記憶する。文書抽出手段12は、属性値とクエリと を参照して、対象となる文書に対して検索処理またはク リッピング処理を行う。

【0014】知識情報記憶手段3には、事象とそれに関する属性、および、属性を構成する属性値を抽出するための情報とが関連付けられて記憶されている。事象特定手段4は、入力された文書と、知識情報記憶手段3に記憶されている知識情報とを照合することにより、文書中に記述されている事象を特定する。属性値抽出手段5は、知識情報記憶手段3を参照して、特定された事象に関する属性の属性値を文書から抽出する。対応付け手段10は、知識情報記憶手段3に記憶されている知識情報を参照して、抽出された属性値と実世界の実体とを1対1に対応付ける処理を行う。文書記憶手段11は、対応付けがなされた属性値と文書または文書の格納場所を特定するための情報とを関連付けて記憶する。文書抽出手

段12は、入力されたクエリに含まれている情報と、文 書記憶手段11に記憶されている属性値とを照合するこ とにより所望の文書を抽出する。

【0015】これにより、対象となる文書に記述されて いる内容を、事象という観点から把握し、把握した事象 を構成する属性の属性値を抽出するとともに、抽出した 属性値を実世界の実体と対応付けることによって生成さ れた情報を参照して文書を検索またはクリッピングする ようにしたので、検索またはクリッピングの精度を向上 させることが可能となる。

[0016]

【発明の実施の形態】以下、本発明の実施の形態を図面 を参照して説明する。図1は、本発明の実施の形態の構 成例を示すブロック図である。この図において、文書入 力部1からは、処理対象の文書が入力される。 ユーザイ ンタフェース部2は、ユーザからのクエリを受け付け る。

【0017】知識情報記憶手段3は、後述する事象やそ の事象に係わる属性に関する情報および固有名を固有コ ードに変換するための情報を記憶している。事象特定手 段4は、知識情報記憶手段3に記憶されている知識情報 (事象の種類に関する情報)を参照して、文書入力部1 またはユーザインタフェース部2から入力された文書や クエリに記述されている事象の種類を特定する。

【0018】ここで、「事象」とは、実世界で生起する 「できごと」を示している。例えば、新聞記事などでは 「A社がXを発売する。」というような実世界で発生し た(または、これから発生する)事象に種々の補足情報 が付加されて記述されていると考える。

【0019】従って、事象特定手段4に対して、例え ば、前述の「A社がXを発売する。」が入力されると、 この文章に記述されている事象は、<新製品の発売>で あると特定されることになる。ここで、<>は、その内 部の語句が抽象化されて得られた概念であることを示し ている。

【0020】なお、新聞記事などのように、記述の対象 となる事象が明確であり、また、その表現様式が限られ ている文書においては、記述された事象のとりうる構造 (以下、事象構造と適宜略記する) にも所定の制約条件 が自ずと生ずることから、このような「事象」に着目し 40 て文書を解析することにより、効果的な処理を行うこと が可能となる。

【0021】属性値抽出手段5は、知識情報記憶手段3 に記憶されている知識情報(所定の事象に係わる属性に 関する情報)を参照して、文書またはクエリから属性値 を抽出する。

【0022】例えば、知識情報記憶手段3は、前述の< 新製品の発売>という事象に関しては、<販売会社>、 <製品情報>、<日付>、および、<変更点>などの属 性を記憶しており、属性値抽出手段5は、事象特定手段 50

4によって特定された事象に対応する属性を知識情報記 億手段3から取得し、その属性に対応する属性値を文書 またはクエリから抽出する。

【0023】例えば、前述の「A社がXを発売する。」 という事象では、属性<販売会社>に対応する属性値 「A社」が取得され、また、属性<製品情報>に対応す る属性値「X」などが抽出される。

【0024】作成日時取得手段6は、文書またはクエリ の作成日時を取得する。時制取得手段7は、文書または クエリを構成する文章の時制 (tense) を取得する。正 規化手段8は、属性値抽出手段5によって抽出された属 性のうち、数値に変換可能なものを選択し、対応する数 値に変換(正規化)する。

【0025】単位変換手段9は、正規化手段8が正規化 した数値の単位を変換する処理を行う。対応付け手段1 0は、知識情報記憶手段3に記憶されている知識情報を 参照して、属性値抽出手段5によって抽出された属性値 を、実世界における実体に対応付ける処理を行う。な お、この「実体」とは、文書に記述されている属性値が 示す実世界の「オブジェクト」を意味している。例え ば、前述の例では、「A社」と呼ばれる企業が複数存在 する場合には、文書中に記述されている「A社」がどの 企業(オブジェクト)を示しているのかを特定する必要 があるので、対応付け手段10は、文書中の他の属性値 (例えば、「社長の名前」や「本社地」など) を参照し て「A社」を特定する。

【0026】文書記憶手段11は、対応付け手段10に よって対応付けがなされた属性値集合と、もとの文書 (または、もとの文書の格納場所を特定する情報) とを 対応付けて記憶する。

【0027】文書抽出手段12は、対応付け手段10か ら供給されたクエリに対応する文書を、属性値を参照し て文書記憶手段11から取得する。そして、重要度算出 手段13によって算出された個々の文書の重要度を参照 し、ある閾値以上の重要度を有する文書を出力する。

【0028】重要度算出手段13は、所定のキーワード の出現頻度などを求めることにより、対象とする文書の 重要度を算出する。図2を参照して、図1に示す実施の 形態を含む通信システムの構成例について説明する。

【0029】図2において、図1に示す文書処理装置2 0は、例えば、インターネットなどのネットワーク21 に接続されている。このネットワーク21には、端末装 置22a、22bや、サーバ23などが接続されてい

【0030】端末装置22a,22bは、その入力部を ユーザが操作して入力したクエリなどを受け付けて、文 書処理装置20に送信するとともに、送信したクエリに 対応する文書を文書処理装置20が送信した場合には、 その文書を受信して、例えば、CRT (Cathode Ray Tu be) モニタなどへ表示出力する。

【0031】サーバ23は、記憶部23aに記憶している文書や画像などの情報を、ネットワーク21を介して、要求を行った装置に対して送信する。文書処理装置20は、端末装置22a,22bなどから送信されたクエリを記憶しておき、例えば、サーバ23から新たな文書が供給された場合には、その文書と前述のクエリとの関連度が高い場合には、端末装置22aまたは端末装置22bに対して送信する。

【0032】次に、以上の実施の形態の動作について説明する。図3は、図1に示す実施の形態において、新た 10な文書が文書入力部1から入力された場合(例えば、図2に示すサーバ23から新たな文書が供給された場合)に実行される処理の一例を説明するフローチャートである。

【0033】このフローチャートが開始されると、以下の処理が実行されることになる。

[S1] 文書入力部1は、新たな文書を入力する。

[S2] 事象特定手段4は、文書に記述されている事象 の種類を特定する。

【0034】即ち、事象特定手段4は、知識情報記憶手 20 段3に記憶されている事象と表現とのマッピング規則情 報(図5参照)を参照して、文書に記述されている事象 の種類を特定する。図5に示すマッピング規則では、

"module" "end"で囲繞された部分が一つの事象(または実体)と表現とのマッピング規則であり、1つの事象に対する表現のバリエーションを記述している。なお、図5に示すマッピング規則の詳細については後述する。

[S3] 属性値抽出手段5は、知識情報記憶手段3に記憶されている知識情報を参照して属性値を抽出する。

【0035】例えば、属性値抽出手段5は、図5に示す「module main」内に記述されている事象のバリエーションのうち、入力された文書に対応する定義に含まれている属性(例えば、<会社情報>、<製品>等)の属性値を、他の「module」や「def」などを参照することにより文書から抽出する。例えば、属性<会社情報>に対応する属性値は、第17行目 \sim 第21行目に記述されている定義および、第12行目 \sim 第15行目に記述されている定義を参照してパターンマッチングを行うことにより、文書から抽出する。

[S4] 正規化手段8は、抽出された属性値に日付表現が含まれているか否かを判定し、日付表現が含まれている場合にはステップS5に進み、それ以外の場合にはステップS7に進む。

[S5] 作成日時取得手段6は、文書が作成された日時を取得し、また、時制取得手段7は、対象となる事象が記述されている文章の時制(tense)を取得する。

[S6] 正規化手段8は、取得した文書作成日時情報と時制情報とを参照して、日付表現を対応する数値に変換する「日付表現変換処理」を実行する。

【0036】なお、この処理の詳細については、図6を 参照して後述する。

[S7] 正規化手段8は、抽出された属性値に金額表現が含まれているか否かを判定し、金額表現が含まれている場合には、ステップS8に進み、それ以外の場合にはステップS11に進む。

[S8] 正規化手段8は、注目している金額表現が規定された通貨単位であるか否かを判定し、規定された通貨単位である場合にはステップS10に進み、それ以外の場合にはステップS9に進む。

【0037】例えば、規定されている通貨単位が「円」 ある場合に、「\$」を単位とする金額表現が存在してい る場合にはステップS9に進む。

[S9] 単位変換手段9は、内蔵されている記憶部に記憶している交換レートを読み出し、規定されている通貨単位に変換する処理を行う。

【0038】例えば、「\$100」という表現が存在している場合に、交換レートが「1\$=130円」であるとすると、「\$100」は「13000円」に変換されることになる。

[S10] 正規化手段8は、金額表現を数値に変換する「金額表現変換処理」を行う。なお、この処理の詳細は、図13を参照して詳述する。

【0039】前述の例では、「13000円」(文字列)が「13000」(数値)に変換される。

[S11] 正規化手段8は、他の数値表現が存在するか否かを判定し、他の数値表現が存在する場合にはステップS12に進み、それ以外の場合にはステップS13に進む。

30 【0040】例えば、「出荷台数50000台」などの 表現が存在する場合には、ステップS12に進む。

[S12] 正規化手段8は、属性値に含まれている数値表現を対応する数値に変換する。例えば、前述の例では、「50000」(文字列)が計算可能な数値「5000」に変換されることになる。

[S13]対応付け手段10は、属性値に固有名(例えば、「橋本電気」等)が含まれているか否かを判定し、含まれている場合にはステップS14に進み、それ以外の場合にはステップS15に進む。

[S14]対応付け手段10は、固有名を抽出し、その 固有名に対応する固有名コードを知識情報記憶手段3か ら取得して付与する。

【0041】例えば、前述の「橋本電気」に対応する固有名コード「00011」が、知識情報記憶手段3から読み出されて付与される。なお、知識情報記憶手段3には、関連する固有名を相互に関連づけて生成した情報が記憶されているので、文書中のある固有名が複数の候補を有する場合には、関連付けられている他の固有名を参照することにより、固有名を正確に特定することが可能となる。

50

【0042】即ち、「橋本電気」に対応する候補が「橋 本電気株式会社」と「株式会社橋本電気」の2つである 場合(同名の会社が存在する場合)には、文書中に記載 されている、例えば、社長名や所在地などと、知識情報 記憶手段3に関連付けられて記憶されている固有名とを 比較することにより、これらの候補を絞り込んで正確な 固有名を取得することができる。

[S15]対応付け手段10は、参照表現(「同」また は「両」などの表現)が存在するか否かを判定し、参照 表現が存在する場合にはステップS16に進み、それ以 10 む。 外の場合にはステップS18に進む。

【0043】例えば、参照表現である(同)が存在する 場合には、ステップS16に進むことになる。

[S16] 対応付け手段10は、参照表現が参照してい る対象を同定する。

【0044】例えば、「橋本電気(中山社長)は、橋本 電算機(同)の独立を・・・」の場合では、参照表現

「同」が参照している対象として「中山社長」を同定す る。なお、この同定方法としては、「同」や「両」が内 挿された括弧"()"が検出された場合には、その括弧 20 より前に出現する括弧内の属性値を、参照表現が参照し ている対象であると同定するようにすればよい。

[S17]対応付け手段10は、参照表現が参照してい る対象に対応する固有コードを取得し、取得した固有名 コードを参照表現に対して付与する。

【0045】前述の例では、「中山社長」の固有コード 「0001」が参照表現「同」に付与されることにな

[S18] 対応付け手段10は、正規化された属性値 (以下、正規化情報と略記する) と、元の文書(また は、元の文書の格納場所を特定するための情報)とを関 連付けて文書記憶手段11に記憶させる。

【0046】以上の処理により、入力された文書に記述 されている事象が特定されるとともに、その事象に係わ る属性の属性値が取得される。そして、取得された属性 値と実世界の実体とが対応付けられて得られた正規化情 報と、もとの文書(または、元の文書の格納場所を特定 するための情報)とが文書記憶手段11に記憶されるこ とになる。

【0047】次に、図3のステップS6に示す、「日付 40 表現変換処理」の詳細について説明する。図6は、図3 に示す「日付表現変換処理」の詳細を説明するフローチ ャートである。このフローチャートが開始されると、以 下の処理が実行されることになる。

[S30] 作成日時取得手段6は、文書の作成日時を取 得して、%docyear, %docmonth, %docday に代入する。 なお、文書の作成日時は、例えば、新聞記事であればそ の記事の発行日を取得する。また、新聞記事以外の文書 であれば、ファイルの属性を参照して、その作成日時を 取得する。

[S31] 正規化手段8は、属性値から日付表現を抽出

10

【0048】例えば、対象となる文章が「橋本電気は新 たなコンピュータを1日に発売。」であれば、日付表現 として「1日」を抽出する。

[S32]正規化手段8は、抽出した日付表現が数字と 「年」、「月」、または、「日」によって構成されてい るか否かを判定し、YESと判定した場合にはステップ S33に進み、それ以外の場合にはステップS34に進

【0049】例えば、前述の「1日」の例では、数字 「1」と「日」とによって構成されていることから、Y ESと判定されてステップS33に進む。

[S33]正規化手段8は、数字変換テーブル (図7参 照)を参照して、日付表現を変換する処理を行う。

【0050】図7に示す数字変換テーブルでは、数字表 現に対応する正規化数値が関連付けられており、ある数 字表現(文字列)が与えられると、その表現に対応する 数値が与えられることになる。

[S34]正規化手段8は、図8に示す日時表現変換テ ーブルを参照して、日時表現を対応する数値に変換す

【0051】図8に示す日時表現変換テーブルでは、表 現と、そのタイプと、対応する正規化数値とが対応付け られている。なお、タイプとは表現の型であり、例え ば、「date」は特定の日時を示し、また、「dat erange」は所定の期間を示している。例えば、1 998年に作成された文書に「昨年の3月4日」という 表現があれば、%year には (%docyear-1) = (1998-1) =1997 が代入され、また、%monthと%dayには、それ ぞれ"3"と"4"が代入される。

【0052】また、1997に作成された文書に「19 98年の春」という表現があれば、%year には"1998" が代入されるので、from 1998-3-1 to 1998-5-30という 正規化値が得られることになる。

【0053】なお、この日時表現テーブルは、一例であ るので、図示したテーブル以外にも種々の実施の形態が 考えられる。

[S35] 正規化手段8は、全ての値が取得されたか否 かを判定し、取得されたと判定した場合にはステップS 37に進み、それ以外の場合にはステップS36に進

【0054】例えば、年月日に対応する全ての値が取得 された場合にはステップS37に進む。

[S36]正規化手段8は、日付の推定処理を行う。な お、この処理の詳細は、図9を参照して後述する。

[S37]正規化手段8は、正規化された数値を%year, %month, %dayにそれぞれ代入して処理を終了する。

【0055】以上の処理によれば、文書に含まれている 50 日付表現を、対応する数値に変換することが可能とな

40

る。次に、図9を参照して図6のステップS36に示す 「日付推定処理」の詳細について説明する。図9に示す フローチャートが開始されると、以下の処理が実行され ることになる。

[S50] 正規化手段8は、%year のみ値が未代入であるか否かを判定し、未代入である場合にはステップS51に進み、それ以外の場合にはステップS52に進む。

[S51] 正規化手段8は、%year 推定処理を行う。なお、この処理の詳細については、図10を参照して後述する。

[S52] 正規化手段8は、%day以外の値が未代入であるか否かを判定し、未代入である場合にはステップS53に進み、それ以外の場合にはステップS55に進む。

[S53] 正規化手段8は、%month推定処理を行う。なお、この処理の詳細については、図11を参照して詳述する。

[S54]正規化手段8は、%year 推定処理を行う。

[S55] 正規化手段8は、%month以外の値が未代入であるか否かを判定し、その結果、未代入である場合にはステップS56に進み、それ以外の場合にはステップS2058に進む。

[S56] 正規化手段8は、%day推定処理を行う。なお、この処理の詳細については図12を参照して詳述する。

[S57] 正規化手段8は、%year 推定処理を行う。

[S58]正規化手段8は、%year 以外の値が未代入であるか否かを判定し、未代入の場合にはステップS59に進み、それ以外の場合には処理を終了する。

[S 5 9] 正規化手段 8 は、推定日時を「from %year-1-1 to %year-12-31」とする。即ち、%year以外の値 30が未代入である場合には、検索漏れが生ずることを防止するために、正規化値をできるだけ広い値に設定する。

【0056】次に、図10を参照して、図8のステップ S51, S54, S57に示す「%year 推定処理」の詳 細について説明する。このフローチャートが開始される と、以下の処理が実行されることになる。

[S60] 正規化手段8は、対象となる文章から時制取得手段7によって取得された時制が未来形である場合にはステップS61に進み、それ以外の場合にはステップS65に進む。

[S61] 正規化手段8は、%docmonth が%monthよりも大きいか否かを判定し、大きいと判定した場合にはステップS62に進み、それ以外の場合にはステップS63に進む。

[S62] 正規化手段8は、%year に値(%docyear+1)を代入する。

【0057】例えば、文書が作成された月が4月である場合に、「3月に・・・する予定である」という表現が文章中にある場合には、この「3月」は、来年の3月を示していると推定されることから、%year には値(%doc 50

year+1)が代入される。

[S63] 正規化手段8は、%docmonth が%month以下であるか否かを判定し、YESと判定した場合にはステップS64に進み、それ以外の場合にはステップS65に進む。

12

[S64] 正規化手段8は、%year に%docyearの値を代入する。

[S65] 正規化手段8は、時制取得手段7によって取得された時制が過去であるか否かを判定し、YESと判定した場合にはステップS66に進み、それ以外の場合には図9の処理に復帰(リターン)する。

[S66] 正規化手段8は、%docmonth の値が%monthの値以上であるか否かを判定し、YESと判定した場合にはステップS67に進み、それ以外の場合にはステップS68に進む。

[S67] 正規化手段8は、%docyearの値を%year に代入する。

[S68] 正規化手段8は、%docmonth の値が%monthの値よりも小さいか否かを判定し、YESと判定した場合にはステップS69に進み、それ以外の場合には図9の処理に復帰する。

[S69] 正規化手段8は、値(%docyear-1)を%year に代入する。

【0058】例えば、文書が作成された月が4月である場合に、「6月に・・・した」という表現が文章中にある場合には、この「6月」は、昨年の6月を示していると推定されることから、%year には値(%docyear-1)が代入される。

【0059】次に、図11を参照して、図9のステップ S53に示す「%month推定処理」の詳細について説明す る。このフローチャートが開始されると、以下の処理が 実行されることになる。

[S80] 正規化手段8は、時制取得手段7によって取得された対象となる文章の時制が未来形である場合にはステップS81に進み、それ以外の場合にはステップS85に進む。

[S81] 正規化手段8は、%docday が%dayよりも大きいか否かを判定し、YESと判定した場合にはステップS82に進み、それ以外の場合にはステップS83に進む。

[S82] 正規化手段8は、%monthに値(%docmonth+1)を代入する。

【0060】例えば、文書が作成された日が2日である場合に、「4日に・・・する予定である」という表現が文章中にある場合には、この「4日」は、次の月の4日を示していると推定されることから、%monthには値(%docmonth+1)が代入されることになる。

[S83] 正規化手段8は、%docday の値が%dayの値以下であるか否かを判定し、YESと判定した場合にはステップS84に進み、それ以外の場合にはステップS8

5に進む。

[S84] 正規化手段8は、%monthに%docmonth の値を 代入する。

[S85] 正規化手段8は、時制取得手段7によって取得された時制が過去であるか否かを判定し、YESと判定した場合にはステップS86に進み、それ以外の場合には図9の処理に復帰(リターン)する。

[S86] 正規化手段8は、%docday の値が%dayの値以上であるか否かを判定し、YESと判定した場合にはステップS87に進み、それ以外の場合にはステップS88に進む。

[S87] 正規化手段8は、%docmonth の値を%monthに 代入する。

[S88] 正規化手段8は、%docday の値が%dayの値よりも小さいか否かを判定し、YESと判定した場合にはステップS89に進み、それ以外の場合には図9の処理に復帰する。

[S89] 正規化手段8は、値(%docmonth-1)を%monthに代入する。

【0061】例えば、文書が作成された日が4日である場合に、「6日に・・・した」という表現が文章中にある場合には、この「6日」は、前の月の6日を示していると推定されることから、%monthには値(%docmonth-1)が代入される。

【0062】次に、図12を参照して、図9のステップ S56に示す「%day推定処理」の詳細について説明す る。このフローチャートが開始されると、以下の処理が 実行されることになる。

[S100] 正規化手段8は、%monthの値が1,3,5,6,8,10,または,12のうちの何れかであるか否かを判定し、YESと判定した場合にはステップS102に進み、それ以外の場合にはステップS102に進む。

[S101] 正規化手段8は、日付情報として「from % year-%month-1 to %year-%month-31」を生成する。

[S102] 正規化手段 8 は、monthの値が4, 6, 9, または、<math>11 のうちの何れかであるか否かを判定し、YES と判定した場合にはステップ S103 に進み、それ以外の場合にはステップ S104 に進む。

[S103] 正規化手段8は、日付情報として「from % 40 year-%month-1 to %year-%month-30」を生成する。

[S104] 正規化手段8は、「年」に関する属性値を 参照して、閏年か否かを判定し、閏年である場合にはス テップS105に進み、それ以外の場合にはステップS 106に進む。

[S105] 正規化手段8は、日付情報として「from % year-%month-1 to %year-%month-29」を生成する。

[S106] 正規化手段8は、日付情報として「from % year-%month-1 to %year-%month-28」を生成する。

【0063】以上の処理によれば、文書に含まれている 50

日付情報が不十分な情報しか含んでいない場合において も、文書の作成日時と、注目する文章の時制とに応じて 日付情報を推定するようにしたので、文書に含まれてい る日付情報を検索を行う際に有効に活用することが可能

【0064】例えば、「来年の春」のような曖昧な表現 も、具体的な数値(例えば、1998年3月1日~19 98年5月31日)に変換(正規化)することが可能と なるので、このような曖昧な表現も検索の際に活用する ことが可能となる。

【0065】次に、図13を参照して、図3のステップ S10に示す「金額表現変換処理」の詳細について説明 する。このフローチャートが開始されると以下の処理が 実行されることになる。

[S120] 正規化手段8は、図14に示す金額表現変換テーブルを参照して、金額表現を対応する数値に変換し、変数xに代入する。

【0066】例えば、「二十万円」という表現では、先ず、「二」が"2"に変換され、「十」が"×10"に、また、「万」が"×10000"に変換されるので、全体として値"200000"が得られることになる。

[S121] 正規化手段8は、金額表現が「以上」で終わるか否かを判定し、「以上」で終わる場合にはステップS122に進み、それ以外の場合にはステップS123に進む。

[S122] 正規化手段8は、正規化表現として「from x to * 」を生成する。ここで、「*」は任意の値を意味している。

【0067】前述の例では、x=2000であるので、「from 2000 to *」が生成される。

[S123] 正規化手段8は、金額表現が「以下」で終わるか否かを判定し、「以下」で終わる場合にはステップS124に進み、それ以外の場合にはステップS125に進む。

[S124] 正規化手段8は、正規化表現として「from * to x 」を生成する。

[S125] 正規化手段8は、金額表現が「台」で終わるか否かを判定し、「台」で終わる場合にはステップS126に進み、それ以外の場合にはステップS128に進む。

[S126] 正規化手段 8 は、正規化表現として「from x to x」を生成する。

[S127] 正規化手段8は、「to」の後のxに含まれている"0"を"9"に全て変換する。

【0068】例えば、「10万円台」という表現では、 x=100000となるので、この場合には「to」の後のxに 含まれている"0"が"9"に全て変換されるので、19 9999 となる。従って、正規化表現としては、「from 10 0000 to 199999」が生成されることになる。

[S128]正規化手段8は、金額表現が「台前半」で

終わるか否かを判定し、「台前半」で終わる場合にはステップS129に進み、それ以外の場合にはステップS 131に進む。

[S129] 正規化手段8は、正規化表現として「from x to x」を生成する。

[S130] 正規化手段8は、「to」の後のxに含まれている最初の"0"を"5"に変換する。

【0069】例えば、「10万円台前半」という表現では、x=100000となる。この場合には「to」の後のxに含まれている最初の"0"が"5"に変換されるので、150000となる。従って、正規化表現としては、「from 100000 to 150000 」が生成されることになる。

[S131] 正規化手段8は、金額表現が「台後半」で終わるか否かを判定し、「台後半」で終わる場合にはステップS132に進み、それ以外の場合には図3の処理に復帰する。

[S132] 正規化手段 8 は、正規化表現として「from x to x」を生成する。

[S133] 正規化手段8は、「from」の後のxに含まれている最初の"0"を"6"に変換する。

[S134] 正規化手段8は、「to」の後のxに含まれている"0"を"9"に変換する。

【0070】例えば、「10万円台後半」という表現では、x=100000となるので、この場合には「to」の後のxに含まれている最初の"0"が"6"にステップS133において変換され、また、「to」の後のxに含まれている"0"が"9"に全て変換されるので、正規化表現としては、「from 160000 to 199999」が生成されることになる。

【0071】以上の処理によれば、例えば、漢数字によって記述されている金額表現を対応する数値に変換するとともに、例えば、「以上」や「台前半」などの曖昧な表現を含む金額表現も対応する数値に変換することが可能となる。

【0072】次に、具体的な例を挙げて以上の実施の形態の動作について説明する。いま、図15に示す文書が図1に示す文書入力部1から入力されたとする。なお、図15に示す例文は、新製品の発売に関する文書である。

【0073】このような文書が文書入力部1から入力さ 40 れると、事象特定手段4は文書に記述されている事象を、知識情報記憶手段3に記憶されている知識情報を参照して特定する(図3のステップS2)。

【0074】図15の例では、図5の第4行目~11行目に記述されている「module main」の中の第1番目の項目(<会社情報>は[、]?<日付>、<製品>を発売した。)に該当することから、この文書に記述されている事象が「新製品の発売」であると判定されることになる。

【0075】なお、図5に示す知識情報では、事象の定 50

義が「module main」 \sim 「end module」によって囲続された部分に記述されている。また、事象の定義の中に含まれている、例えば、<会社情報>などの属性は、「module」や「def」などにおいて定義されている。例えば、属性<会社情報>は、第17行目 \sim 第21行目の「module」内に定義されており、その内容は、(<業種>、<会社名>)、(<業種2>&連結語;<会社名>)、および、(<会社名>)の3種類である。

16

【0076】ここで、<業種>に関する定義は、第12行目の「def」の後に記述されており、(.*メーカー.*会社|.*大手|.*開発|.*販売|.*製造ー.*業)の中の何れかに該当するものが属性<業種>の属性値であるとされる。従って、「パソコンメーカ」や「パソコン大手」などの表現は、<業種>の属性値であると判定される。なお、「一」は「or」を意味している。

【0077】また、同意語または類義語を含めて定義を行う場合には、第19行目に示されているように、同意語を含める部分を「&」と「;」の間に挿入する。この例では、「連結語」が同意語または類義語を含む部分となり、その詳細は、第16行目に定義されており、「連結語」=(を専門とする|である|している|する|の)となる。従って、「オフィスオートメーションを専門とする橋本電機」という表現は、会社情報の第2番目の定義(<業種2>&連結語;<会社名>)に該当することになる。

【0078】このように、本実施の形態においては、トップダウン的な処理が実行されることから、文脈に応じたパターンマッチングが可能となる。以上のような処理によって事象の種類が特定されると、時制取得手段7は、事象が記述されている文章を取得し、その時制情報を取得する。図15に示す文書の例では、その時制は過去形(「発売した」)であるので、「過去形」が時制情報として取得される。なお、このようにして取得された時制は、図16の第2行目に示すように「アスペクト=過去」として、正規化情報に付加される。

【0079】次に、属性値抽出手段5は、特定された事象の種類に応じて、属性値を抽出する(図3のステップS3)。即ち、属性値抽出手段5は、図5に示す知識情報と文書との間でパターンマッチングを行うことによって属性値を抽出する。

【0080】図15の例では、例えば、<組織名>として「橋本電機」が抽出され、また、新たに発売する<製品情報>の<種別>としては「JCN互換パソコン」が抽出され、その<製品名>としては、「GNWシリーズ」が抽出されている。

【0081】続いて、正規化手段8は、文書に日付表現が存在するか否かを判定し(図3ステップS4)、存在する場合には対応する数値に変換する処理を行う。図15に示す文書では、「十八日」という表現が含まれてい

ることから、正規化手段8は、図3に示すステップS5 において文書作成日時情報と時制情報とを取得して、ス テップS6において日付表現変換処理を行う。

【0082】例えば、文書作成日時が「1993年10 月19日」であるとすると、図16の第6行目に示すよ うに、「発表日付」としてそのタイプが「date」であ り、また、その値が「1998-10-18」である情報が正規化 情報に付加されることになる。

【0083】続いて、正規化手段8は、図3のステップ S7において、金額表現が存在するか否かを判定する。 図15に示す文書では、「十七万八千円」などの表現が あることから、ステップS8に進み、そこで、規定され た通貨単位か否かが判定される。例えば、規定された通 貨単位が「円」であるとし、対象となる表現が前述の 「十七万八千円」である場合には、ステップS10に進 むことになる。

【0084】なお、「\$150」などの表現が含まれて いる場合には、ステップS9において交換レート(1 \$ *

> 0001 橋本電機<会社名> 00011 橋本太郎<社長名> 00012 岡山県<所在地>

取得された「橋本電機」に対する候補が複数存在する場 合には、橋本電機に関連付けられて記憶されている他の 固有名(橋本太郎、岡山県)などが文書中に含まれてい ないか判定され、候補が絞り込まれることになる。

【0089】そして、ステップS14において、絞り込 みの結果得られた固有名コード(例えば、0001) が、正規化情報に付与されることになる(図16第4行 目参照)。

【0090】ステップS15では、対応付け手段10 は、参照表現が存在するか否かを判定する。図15に示 す例では、参照表現は存在しないから、NOと判定され てステップS18において、生成された正規化情報と文 書(または、文書が格納されている場所を示す情報)と を文書記憶手段11に記憶して処理を終了する。

【0091】図17は、他の文書例を示している。ま た、図18は、図17に示す文書を処理して得られた正 規化情報の一例を示している。図18の第3行目に示す ように、図17に示す文書に記述されている事象は、合 併情報(field =合併情報)であり、その時制は過去 (アスペクト=過去) である。また、「発表した」とい 40 う表現が第1番目の文章中にないことから、第2行目に 示すように、「文末表現=発表述語なし」とされてい る。

【0092】更に、第5行目から第27行目に示されて いる「合併主体組織情報」の内容としては、第8行目と 第18行目に示されている北海道大木リフトと、東北海 道大木リフトとが合併する主体組織であり、それ以外の 行には、これらの組織を補足するための<合併組織補足 情報>が記載されている。

【0093】第34行目以降には、分析の対象となった 50

*=130円)に応じて、通貨単位の変換が行われた後、 ステップS10に進む。

【0085】ステップS10では、文字列「十七万八千 円」が、値"178000"に変換される。続くステップS1 1では、他の数値表現が存在するか否かが判定される が、図15に示す例の第1番目の文章には、日付表現以 外の数値表現は存在しないことから、ステップS13に 進む。

【0086】ステップS13では、対応付け手段10が 固有名が存在するか否かを判定する。図15の例では、 固有名「橋本電機」が存在することから、ステップS1 4に進む。

【0087】ステップS14では、対応付け手段10が 知識情報記憶手段3に記憶されている知識情報のうち、 橋本電機に対応する情報を取得する。なお、この情報 は、例えば、以下のような情報である。

[0088]

文以外の残りの文章が記載されている。なお、この例で は、図17の第3行目に「同」という参照表現が含まれ ているので、図18の第23行目に示すように「参照先 =前」という記述が追加され、参照表現「同」が、第1 3~第16行目に示されている「芥川龍太郎(025 1)」(要素2)であることが示されている。

【0094】次に、以上のようにして生成された正規化 情報を参照して、文書を検索する場合の処理の一例につ いて説明する。図19は、図1に示すユーザインタフェ ース部2に表示される入力画面の表示例である。この例 では、製品の販売情報が記載された文書を検索の対象と している。即ち、<製品の販売>が事象として記述され た文書が検索の対象とされる。

【0095】この例では、第1番目に示すボックス「組 織名」に、製品を発売した組織名が入力される。また、 第2番目に示すボックス「製品種」には、製品の種類が 入力される。更に、ボックス「価格」には製品の価格の 範囲が入力される。ボックス「発売日」には、発売され た日の範囲が入力される。なお、最下行に表示されてい るボタン「検索」は、全ての入力が終了し、検索を開始 する場合に操作される。

【0096】図20は、図19に示す画面に所定のクエ リが入力された場合の入力例を示している。この例で は、組織名として「AAA」が、また、製品種として 「パソコン」が入力されている。

【0097】更に、価格は、「100000」円以上 「300000」円以下とされており、発売日は「19 97」年「1」月「1」日から「1997」年「6」月 「30」日までとされている。

【0098】このような入力画面から入力されたクエリ

は、各入力項目の属性を示す情報が付与された後、事象 特定手段4、属性値抽出手段5、および、対応付け手段 10を介して、文書抽出手段12に供給される。なお、 付与される情報としては、例えば、「AAA」に対して はタグ < 組織名 > が付与される。また、価格はタグ < 価 格 type=price unit= 円 value = " from 100000 to 30 0000" >に変換される。更に、発売日は、タグ<発売日 type=date value= "from 1997-1-1 to 1997-6-30" >に変換される。

【0099】文書抽出手段12は、ユーザインタフェー 10 ス部2から供給されたクエリとタグとに対応する属性値 を有する文書を文書記憶手段11から取得する。即ち、 文書記憶手段11には、元の文書とともに正規化情報が 記憶されているので、文書抽出手段12は、この正規化 情報に含まれている属性値と、クエリのタグとを照合す ることにより、所望の文書を抽出する。

【0100】このようにして検索された結果は、図示せ ぬ表示装置に表示出力される。図21は、検索結果を表 示する画面のテンプレートを示している。この例では、 検索結果の属性値として「組織名」、「製品種」、「製 20 品名」、「価格」、「発売日」、および、「見出し」が 表示される。

【0101】図22は、実際の表示例を示している。こ の例の第1行目の項目は、「AAA」という組織が、デ スクトップ型のパソコンを、200000~299999円で、1997 /02/29に発売しており、その文書の見出しは「低価格パ ソコン発売」であることを示している。

【0102】図23は、図1に示すユーザインタフェー ス部2に表示される入力画面の他の表示例である。この 例では、「組織の合併情報」が記載された文書を検索の 対象としている。即ち、組織の合併が事象として記述さ れた文書が検索の対象とされる。この例では、第1番目 と第2番目に示すボックス「組織名」に、合併する組織 名が入力される。また、ボックス「合併日」には、合併 が行われる日の範囲が入力される。なお、最下行に表示 されているボタン「検索」は、全ての入力が終了した後 に、検索を開始する場合に操作される。

【0103】図24は、図23に示す入力画面に所定の クエリが入力された場合の入力例を示している。この例 では、組織名として「AAA」が、また、合併日として 「1997」年「1」月「1」日から、「1997」年 「12」月「31」日までが入力されている。

【0104】このような入力画面において、ボタン「検 索」が操作されると、前述の場合と同様にタグが生成さ れ、文書記憶手段11に記憶されている正規化情報と、 このタグとを照合することにより、文書が検索される。

【0105】図25は、図24の検索結果を表示する画 面の表示例である。この表示例では、検索結果の属性と して「組織名」、「組織名」、「新組織名」、「合併 日」、および、「見出し」が表示される。

【0106】図26は、実際の表示例を示している。こ の例では、検索結果の文書には、組織名が「AAA」お よび「BBB」である会社が「1997/04/01」に合併し、 新組織名は「CCC」であることが示されており、ま た、その文書の見出しは、「AAA、BBB、2社合併」であ ることが示されている。

20

【0107】以上の実施の形態によれば、検索の対象と なる事象に対応した入力画面を用意して、その入力画面 から必要な項目を入力することにより、所望の文書が取 得されることになる。ところで、文書記憶手段11に記 憶されている文書には、前述の正規化情報が関連付けら れて記憶されているので、その正規化情報を参照するこ とにより、例えば、対象とする文書に、新たに発売され たパソコンの価格が「二十五万円」と漢数字で記載され ているような場合においても、「200000」円~「30000 0」円と記述されたクエリによって取得されることにな る。

【0108】なお、以上の実施の形態においては、検索 しようとする事象に対応した入力画面から所定の項目を 入力し、入力された項目に対応する文書を検索するよう にしたが、クエリを文章として入力し、入力された文章 に対して正規化処理を行った後、対応する文書を検索す るようにしてもよい。以下、そのような方法により、ク エリを正規化する処理の一例について、図27を参照し て説明する。このフローチャートが開始されると以下の 処理が実行されることになる。

[S151] ユーザインタフェース部2は、文章として 記述されたクエリを入力する。

[S152] 事象特定手段4は、クエリに記述されてい る事象の種類を特定する。即ち、事象特定手段4は、知 識情報記憶手段3に記憶されている事象と表現とのマッ ピング規則情報(図5参照)を参照して、クエリに記述 されている事象の種類を特定する。

[S153] 属性値抽出手段5は、知識情報記憶手段3 に記憶されている知識情報を参照して属性値を抽出す

[S154] 正規化手段8は、抽出された属性値に日付 表現が含まれているか否かを判定し、日付表現が含まれ ている場合にはステップS155に進み、それ以外の場 合にはステップS157に進む。

[S155] 作成日時取得手段6は、クエリが作成され た日時を取得し、また、時制取得手段7は、クエリの時 制(tense)を取得する。

[S156] 正規化手段8は、取得したクエリ作成日時 情報と時制情報とを参照して、日付表現を対応する数値 に変換する「日付表現変換処理」を実行する。なお、こ の処理の詳細については、図6を参照して既述したの で、その説明は省略する。

S157]正規化手段8は、抽出された属性値に金額

ている場合には、ステップS158に進み、それ以外の 場合にはステップS161に進む。

[S158] 正規化手段8は、注目している金額表現が 規定された通貨単位であるか否かを判定し、規定された 通貨単位である場合にはステップS160に進み、それ 以外の場合にはステップS159に進む。例えば、規定 されている通貨単位が「円」ある場合に、「\$」を単位 とする金額表現が既述されている場合にはステップS1 59に進む。

[S159] 単位変換手段9は、内蔵されている記憶部 10 に記憶している交換レートを読み出し、規定されている 通貨単位に変換する処理を行う。

【0109】例えば、「\$100」という表現が存在し ている場合に、交換レートが「1\$=130円」である とすると、「\$100」は「13000円」に変換され ることになる。

[S160] 正規化手段8は、金額表現を数値に変換す る「金額表現変換処理」を行う。なお、この処理の詳細 は、図13を参照して既述したので、その説明は省略す る。

【0110】前述の例では、「13000円」(文字 列)が「13000」(数値)に変換されることになる。

[S161] 正規化手段8は、他の数値表現が存在する か否かを判定し、他の数値表現が存在する場合にはステ ップS162に進み、その他の場合にはステップS16 3に進む。

【0111】例えば、「出荷台数50000台」などが 存在する場合には、ステップS162に進む。

[S162]正規化手段8は、属性値に含まれている数 値表現を対応する数値に変換する。例えば、前述の例で 30 は、文字列「50000」が計算可能な数値「5000」に 変換されることになる。

[S163] 対応付け手段10は、属性値に固有名(例 えば、「橋本電気」等)が含まれているとう を判定 し、含まれている場合にはステッ し進み、そ れ以外の場合にはステップS1(Land Edg.

[S164]対応付け手段10/ 量有名を抽出し、そ の固有名に対応する固有名コート 温温情報記憶手段3 から取得して属性値に付与する。

【0112】例えば、前述の「橋 [1] に対応する固 40 有名コード「00011」が、知識に報記憶手段から読 み出されて付与される。なお、知識情報記憶手段3に は、関連する固有名を相互に関連づけて生成した情報が 記憶されているので、ある固有名が複数の候補を有する 場合には、関連付けられている他の固有名を参照するこ とにより、固有名を正確に特定することが可能となる。

【0113】即ち、「橋本電気」に対応する候補が「橋 本電気株式会社」と「株式会社橋本電気」の2つでいる 場合(同名の会社が存在する場合)には、クエリ中二記 載されている、例えば、社長名や所参地などと「知識情」50 報記憶手段3に関連付けられて記憶されている固有名と を比較することにより、これらの候補を絞り込んで正確 な固有名コードを取得することができる。

22

[S165] 対応付け手段10は、参照表現(同または 両などの表現)が存在するか否かを判定し、参照表現が 存在する場合にはステップS166に進み、それ以外の 場合にはステップS168に進む。

【0114】例えば、参照表現である(同)が存在する 場合には、ステップS166に進むことになる。

[S166]対応付け手段10は、参照表現が参照して いる対象を同定する。

【0115】例えば、「橋本電気(中山社長)は、橋本 電算機(同)の独立を・・・」の場合では、参照表現

「同」が参照している対象として「中山社長」を同定す る。なお、この同定方法としては、「同」や「両」が内 挿された括弧"()"が検出された場合には、その括弧 より前に出現する括弧内の属性値を、参照表現が参照し ている対象であると同定するようにすればよい。

[S167]対応付け手段10は、参照表現が参照して 20 いる対象に対応する固有コードを取得し、取得した固有 コードを参照表現に対して付与する。

【0116】前述の例では、「中山社長」の固有コード 「00010」が参照表現「同」に付与されることにな

[S168] 対応付け手段10は、以上のようにして生 成されたクエリの正規化情報を、文書抽出手段12に供 給する。その結果、文書抽出手段12は、以上のように して生成されたクエリの正規化情報を参照して、文書記 憶手段11に記憶されている文書を検索する。

【0117】例えば、クエリとして「橋本酒造が純米 酒、橋本を発売した。」が入力された場合には、事象特 定手段4は、知識情報記憶手段3に記憶されている知識 情報を参照し、入力されたクエリが「新製品の発売」と いう事象を示していることを特定する。

【0118】属性値抽出手段5は、<組織名>として 「橋本酒造」を抽出し、また、<製品種>として「純米 酒」を、また、<製品名>として「橋本」を抽出する。 対応付け手段10は、「橋本酒造」に対応する固有名コ ードが存在する場合には、その固有名コードを取得して 付与する。例えば、「橋本酒造」の固有名コードが"0 111"である場合には、<組織名>橋本酒造(011 1) </組織名>というタグが生成されることになる。

【0119】文書抽出手段12は、以上のようにして生 成された正規化情報を参照して、文書記憶手段11から 該当する文書を抽出する。即ち、文書抽出手段12は、 組織名タグと固有名コード(0111)が付けられた

「橋本酒造」、製品種タグが付けられた「橋本」、およ び、製品名タグが付けられた「橋本」を含み、その事象 が「新製品の発売」である文書を文書記憶手段11から 抽出する。

【0120】このような処理によれば、例えば、「橋本さんは、橋本酒造製の純米酒を注文した。」という一文が含まれている文書が検索結果として取得されることを防止することができる。即ち、クエリと文書の正規化情報には、抽出された属性を示すタグがそれぞれ付与されていることから、例えば、<製品名>である「橋本」を、<人名>と混同すること防止することができる。

【0121】次に、以上の実施の形態により文書をクリッピングする場合の処理の一例について説明する。図29は、文書をクリッピングする場合に、ユーザから送信10されたクエリを正規化する処理の一例を説明するフローチャートである。このフローチャートが開始されると、以下の処理が実行されることになる。

[S180] ユーザインタフェース部 2 は、所定のユーザからのクエリを入力する。 [S181] 事象特定手段 4、属性値抽出手段 5、および、対応付け手段 10 は、図 27 および図 28 のステップ S151 ~ S167 の処理を実行して、クエリを正規化する。

[S182] 文書抽出手段12は、正規化されたクエリ (正規化情報)と、それを送信したユーザを特定する情 20 報とを関連付けて記憶する。

[S183] 文書抽出手段12と重要度算出手段13 は、文書記憶手段11に記憶されている文書と、ユーザ 毎のクエリの関連度を判定する「関連度判定処理」を実 行する。なお、この処理の詳細は、図30を参照して後 述する。

【0122】次に、図30を参照して、図29に示す「関連度判定処理」の詳細について説明する。このフローチャートが開始されると、以下の処理が実行されることになる。

[S201] 重要度算出手段13は、正規化情報が付与された文書と、正規化されたクエリとの関連度をユーザ単位で計算する。

【0123】なお、計算方法としては、例えば、正規化されたクエリに含まれている重要表現を対象となる文書がいくつ含んでいるかに応じてスコアリングを行い、スコアの高い文書を関連度の高い文書とする方法を採用することができる。

[S202] 文書抽出手段12は、重要度算出手段13 の計算結果を参照し、関連度の高い文書を抽出する。

[S203] 文書抽出手段12は、正規化したクエリに含まれている日付、金額、および、数値が、文書の正規化情報に含まれているそれらの値と一致する文書を抽出する。

[S204] 文書抽出手段12は、一致した文書をネットワーク21を介してユーザに送付する。

【0124】続いて、図31を参照して、例えば、サーバ23から新たな文書が送信されてきた場合に、文書処理装置20において実行される処理の一例を説明する。 このフローチャートが開始されると、以下の処理が実行 50 されることになる。

[S230] 文書入力部1は、ネットワーク21を介して、例えば、サーバ23から新たな文書の入力を受ける。

[S231] 事象特定手段4、属性値抽出手段5、および、対応付け手段10は、文書の正規化処理を実行する。

【0125】即ち、事象特定手段4、属性値抽出手段5、および、対応付け手段10は、図3および図4に示す処理を実行することにより入力された文書に対応する正規化情報を生成する。

[S232] 文書抽出手段12および重要度算出手段13は、図30に示す「関連度判定処理」を実行する。その結果、生成された正規化情報に一致するクエリが存在している場合には、そのクエリを送信したユーザに対して、新たに入力された文書が送付される。

【0126】以上の処理によれば、新たな文書が入力された場合には、入力された文書の正規化情報と、各ユーザの正規化されたクエリとの関連度を算出して、関連度が高い場合には対応するユーザに対して文書を送信するようにしたので、ユーザの要求に適合した文書を正確に選択して送信することが可能となる。

【0127】なお、上記の処理機能は、コンピュータによって実現することができる。その場合、文書処理装置が有すべき機能の処理内容は、コンピュータで読み取り可能な記録媒体に記録されたプログラムに記述されており、このプログラムをコンピュータで実行することにより、上記処理がコンピュータで実現される。コンピュータで読み取り可能な記録媒体としては、磁気記録装置や半導体メモリ等がある。

【0128】市場に流通させる場合には、CD-ROM (Compact Disk Read Only Memory)やフロッピーディスク等の可搬型記録媒体にプログラムを格納して流通させたり、ネットワークを介して接続されたコンピュータの記憶装置に格納しておき、ネットワークを通じて他のコンピュータに転送することもできる。コンピュータで実行する際には、コンピュータ内のハードディスク装置等にプログラムを格納しておき、メインメモリにロードして実行するようにすればよい。

40 [0129]

【発明の効果】以上説明したように本発明では、対象となる文書に記述されている事象を特定し、特定された事象に関する属性の属性値を抽出し、抽出した属性値と実世界の実体とを対応付けすることによって生成された情報を参照して、文書を検索またはクリッピングするようにしたので、各属性値を正確に認識して文書を検索またはクリッピングすることが可能となるので、結果として、文書の検索またはクリッピング精度を向上させることが可能となる。

【図面の簡単な説明】

(14)

【図1】本発明の実施の形態の構成例を示すブロック図である。

【図2】図1に示す文書処理装置を含む通信システムの 構成例である。

【図3】文書の正規化処理の一例を説明するフローチャートである。

【図4】文書の正規化処理の一例を説明するフローチャートである。

【図5】知識情報の一例を示す図である。

【図6】図3に示す日付表現変換処理の詳細を説明する 10 フローチャートである。

【図7】数字変換テーブルの一例を示す図である。

【図8】日時表現変換テーブルの一例を示す図である。

【図9】図6に示す日付推定処理の詳細を示すフローチャートである。

【図10】図9に示す%year 推定処理の詳細を説明するフローチャートである。

【図11】図9に示す‱onth推定処理の詳細を説明するフローチャートである。

【図12】図9に示す%day推定処理の詳細を説明するフ 20 ローチャートである。

【図13】図3に示す金額表現変換処理の詳細を説明するフローチャートである。

【図14】金額表現変換テーブルの一例を示す図である。

【図15】図1に示す実施の形態に入力される文書の一例である。

【図16】図15に示す文書を処理した結果生成される正規化情報の一例である。

【図17】図1に示す実施の形態に入力される文書の他 30の一例を示す図である。

【図18】図17に示す文書を処理した結果生成される 正規化情報の一例である。

【図19】製品販売情報に関する文書を検索する際の入力画面の一例である。

【図20】図19に示す入力画面に入力がなされた場合の一例である。

【図21】図19に示す入力画面に対応する検索結果表*

* 示画面の一例である。

【図22】図20に示す入力画面に対応する検索結果の 画面の一例である。

【図23】組織合併情報に関する文書を検索する際の入力画面の一例である。

【図24】図23に示す入力画面に入力がなされた場合の一例である。

【図25】図23に示す入力画面に対応する検索結果表示画面の一例である。

【図26】図24に示す入力画面に対応する検索結果の画面の一例である。

【図27】 クエリに対する正規化処理の一例を説明するフローチャートである。

【図28】 クエリに対する正規化処理の一例を説明するフローチャートである。

【図29】文書のクリッピングを行う場合において、ユーザからのクエリに対する処理の一例を説明するフローチャートである。

【図30】図29に示す関連度判定処理の詳細を説明するフローチャートである。

【図31】文書のクリッピングを行う場合において実行される、文書に対する処理の一例を説明するフローチャートである。

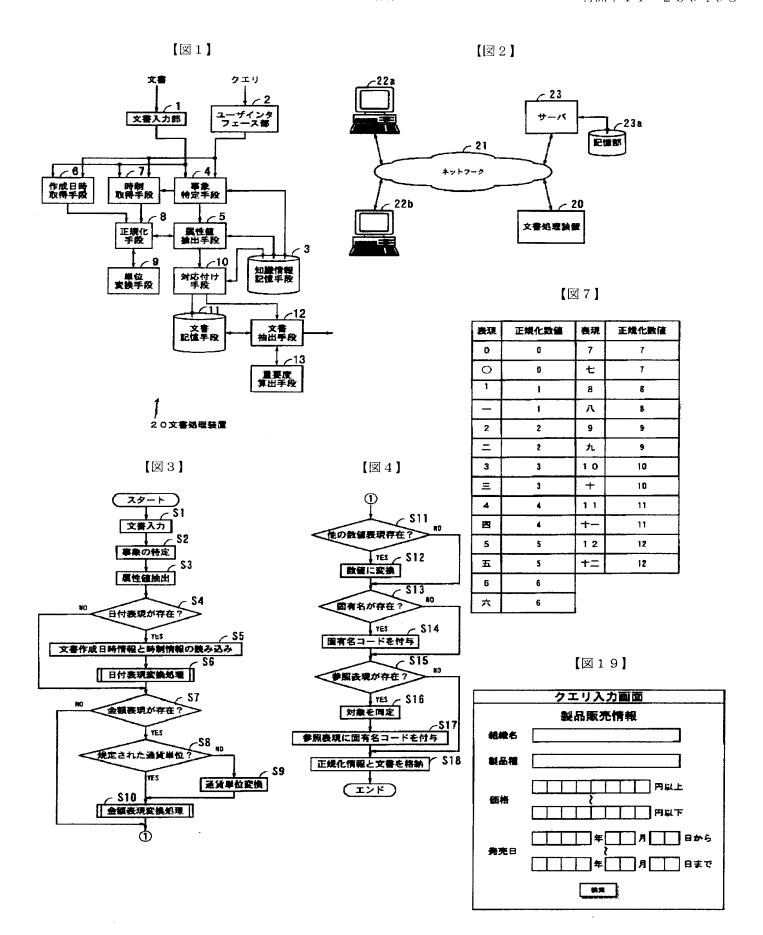
【符号の説明】

- 1 文書入力部
- 2 ユーザインタフェース部
- 3 知識情報記憶手段
- 4 事象特定手段
- 5 属性值抽出手段
- 6 作成日時取得手段
- 7 時制取得手段
- 8 正規化手段
- 9 単位変換手段
- 10 対応付け手段
- 1 1 文書記憶手段1 2 文書抽出手段
- 13 重要度算出手段

【図15】

【図17】

大木リフトの道内販売子会社、北海道大木フォークリフト (石狩香内石狩町、ボ川龍太郎社長)と東北海道大木フォー クリフト(十勝管内茅室町、同)が一日、合併した。 フトが全国で進めている販売強化策に基づくもので、経営を 一元化することにより、効率的な営業体制を整える狙い。 新社の名称は北海道大木フォークリフトで、社長には芥川社 長が献任した。資本金は二億四千万円、従業員は百三十人。

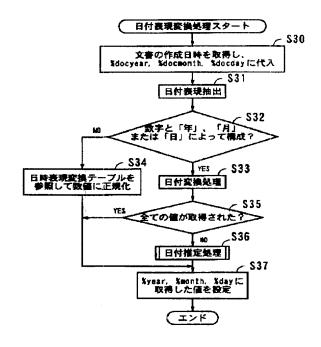


【図5】

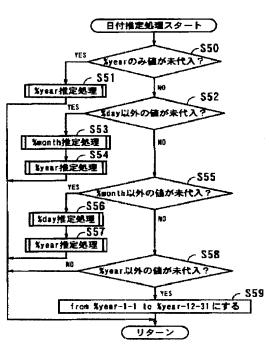
[図8]

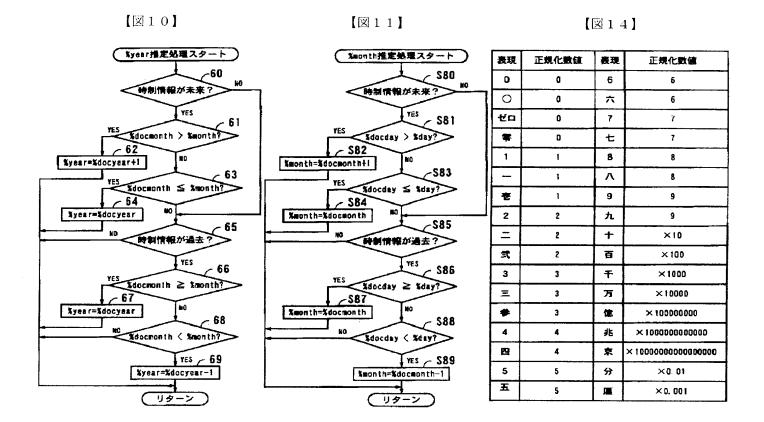
表現	type	対応する正規化数値
昨年	date	%docyear - i
去年	date	Mocyear - L
一昨年	date	%docyear - 2
前年	date	%docyear - [
来年	date	%docyear + L
更年	date	%docyear + 1
本年	date	%docnonth
先月	date	%docmonth - 1
前月	date	%docmonth - 1
来月	date	%docmonth + 1
今月	date	Kdocsonth
作品	date	%docday - 1
前 巨	date	%docday - i
明日	date	%docday + I
今日	date	%docday
本日	date	%docday
月初め	daterange	from %year-%month-1 to %year-%month-10
月末	daterange	from %year=%sonth=21 to %year=%sonth=31
上旬	daterange	(ron Nyear-Mmonth-1 to Nyear-Mmonth-10
中旬	dat erange	from %year-%month-11 to %year-%month-26
下旬	daterange	from %year-%month-21 to %year-%month-31
平成	date	%docyear + 1988
春	daterange	from %year-3-1 to %year-5-31
夏	daterange	from %year-6-1 to %year-8-31
秋	daterange	from %year-9-1 to %year-11-30
冬	daterange	from Myear-12-1(o Myear-2-29
右正月	daterange	from %????-1-1 to %????-1-7
ゴールデンウィーク	daterange	from %????-4-26 to %????-5-5
GW	daterange	(roo \$????-4-26 to \$????-5-5
クリスマス	daterange	from \$?????-12-1to \$????-12-25
入学式シーズン	daterange	from %????-4-1 to %????-4-30
受験シーズン	daterange	from %?????-1-10 to %????-3-30
推照	daterange	from \$7777-6-1co \$7777-7-10

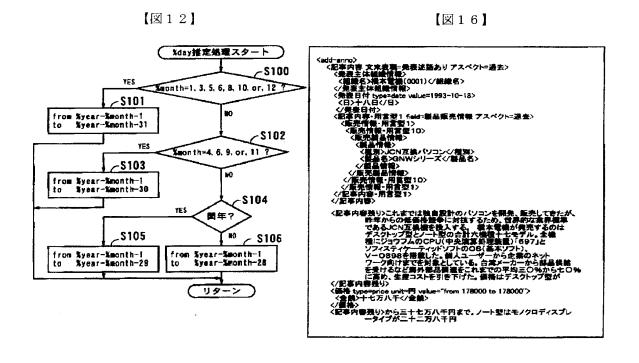
[図6]



【図9】







【図13】

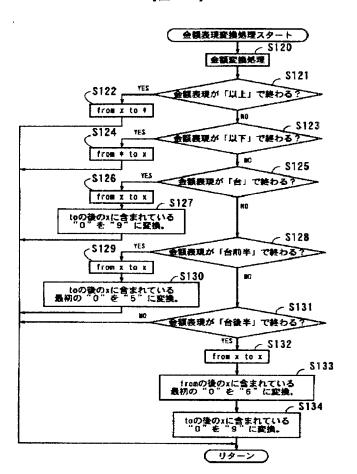
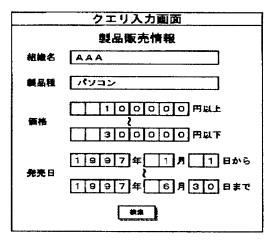


図18]

```
(和書内等) 文来表著=発表述類なし〉
《記事内事:用言型0 5 feld=合併信報 アスペクト=過去〉
《音序主体組織情報 type=合併工作の20/5 偏極機能 〉
《音序主体組織情報 type=合併工作の20/5 偏極機能 〉
《信儀機能分末本リフト(202)/5 偏極機能 >
《信儀機能分末本リフト(202)/5 偏極機多〉
《信義性 是不力オークリフト(202)/5 偏極名〉
《音乐 表示直大本フォークリフト(202)/5 偏極名〉
《音乐 表示直大本フォークリフト(202)/5 偏極名〉
《音乐 音乐 表示直大本フォークリフト(202)/5 偏極名〉
《音乐 音乐 教士 文字=要素)
《医治 子月川龍太郎(2025)/5 氏名〉
《歌北 景景教士 2 type=要素)
《医治 2 要素教士 2 type=要素)
《自然 音乐 教士 2 type=要素》
《自然 音乐 教士 2 type=要素》
《国教 2 要素教士 2 type=要素 参照タイプ=問1 参照先=前(0251)》
《書家 2 要素教士百/5 無要素》
《重新表现》同《多重要素》
《音乐 主作 性 医性 经 2 type=要素 参照タイプ=問1 参照先=前(0251)》
《音乐 表示 表示 2 type=要素 参照タイプ=問1 参照先=前(0251)》
《音乐 文字 2 等素教士2 type=要素 参照タイプ=問1 参照先=前(0251)》
《音素 表示教士2 type=要素 参照タイプ=問1 参照先=前(0251)》
《音素 表示教士2 type=要素 参照タイプ=問1 参照先=前(0251)》
《音素 表示教士2 type=要素》
《古佛 日代日》
《古典 写》)
《記事内書 用言型(0)
《記事内書 用言型(0)
《記事内書 用言型(0)
《記事内書 用言型(0)
《記事内書 現立(1)
《日代日 type=price unit=門 value=from 240000000 to 240000000)
《香本金)工 使用 干 万/6 素 最 は 百 三 十 人。《/記事 内 章 残り》
《古書 内 章 残り》、 使素 最 は 百 三 十 人。《/記事 内 章 残り》
```

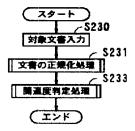
【図20】



【図21】

検索結果表示画面							
製品販売情報							
製品機	製品名	価格	発売日	見出し			
	-						
	製品機	製品則	製品販売情報	製品販売情報			

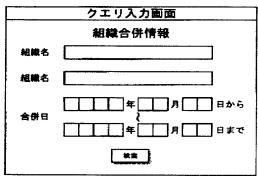
【図31】



【図22】

【図23】

	検索結果表示面面						
		製品	反売情報				
組織名	製品種	製品名	価格	発売日	見出し		
AAA	デスクトップ型 パソコン		200, 000~ 299, 999	1997/02/29	価値格パソコ ン発売		
A A A	ディスプレイ 一体型パソコン	88888	268, 000	1997/03/01	BBBBB新 シリーズ発売		
A A A	カラーノート パソコン	cccc	298, 000	1997/04/11	AAA新発売		
AAA	互換型パソコン	DDDDD	178, 000	1997/05/20	互换型機発売		



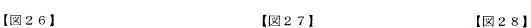
[図24]

【図25】

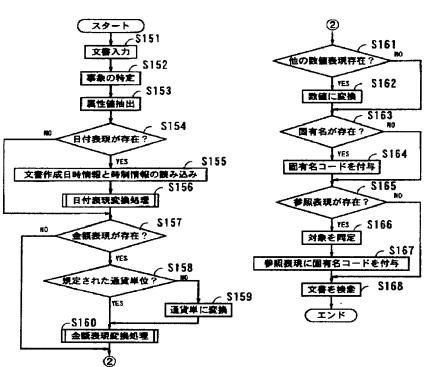
【図29】

クエリ入力画面						
	組織合併情報					
粗糙名	AAA					
組織名						
合併日	1997年 1月 1日から					
W.R.						

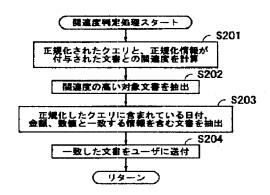




検索結果表示画面								
	組織合併情報							
組織名	組織名	新組織名	合併日	見出し				
AAA	888	ccc	1997/04/01	AAA, BBB, 2 社合 併				



【図30】



フロントページの続き

(72)発明者 落谷 亮

神奈川県川崎市中原区上小田中4丁目1番 1号 富士通株式会社内 (72)発明者 西野 文人

神奈川県川崎市中原区上小田中4丁目1番 1号 富士通株式会社内